

- 
- 
- 
- 
- 

# IF-705 – Automação Inteligente

## Algoritmos Evolucionários e Controle. Continuação

Aluizio Fausto Ribeiro Araújo  
Universidade Federal de Pernambuco  
Centro de Informática - CIn  
Departamento de Sistemas da Computação  
aluizioa@cin.ufpe.br



- 
- 
- 
- 
-

# Sumário

- Recapitulação
- AEs e Controle:
  - Problemas Multi-Objetivos
  - Tratamento de Restrições
  - Controle Robusto
  - Integração do Sistema
- Exemplo de Aplicação

# Recapitulação

- Problemas que envolvem engenharia de controle, tornam-se cada vez mais complexos devido a necessidade de otimizações múltiplas sobre variáveis de controle nem sempre mensuráveis.
- A Formalização matemática é escassa e há grandes problemas em se utilizar a teoria clássica de controle.
- No contexto de controle inteligente os AEs são vistos como uma metodologia de busca robusta e de otimização, que têm sido utilizados em inúmeros problemas complexos.
- Os AEs são flexíveis e podem se adaptar às restrições de cada tipo de problema.

# Recapitulação

- Para um problema que envolve controle, sob o ponto de vista de um AE, este último deve possuir na sua representação genética:
  - As variáveis do sistema de controle;
  - As restrições do sistema de controle;
  - A avaliação do desempenho do sistema de controle;
  - As variáveis do próprio EA;
  - As variáveis que influenciam na função de custo.

# Recapitulação

- As variáveis descritas anteriormente podem ser:
  - Reais
  - Inteiras;
  - Simbólicas
    - Estrutura com funções e terminais de entrada e saída;
    - Diagramas de bloco que podem representar: a planta, o controlador, ou o sistema de controle inteiro.

# Recapitulação

- A escolha da função de custo é essencial para o desempenho de qualquer AE.
- Todos os objetivos devem estar inclusos na função de custo.
- Por isso sua forma depende fortemente do problema em questão.
- Ela deve apresentar, em geral, valor(es) real(is) positivo(s).

# Recapitulação

- A aplicação de EAs para controle de engenharia pode ser classificada em duas áreas principais:
  - design e análise off-line
  - adaptação e ajuste on-line.
- A maioria das aplicações recentes dos EAs para controle são feitas quando os métodos convencionais não são adequados, problemáticos ou indisponíveis.

# AEs e Controle: Problemas Multi-Objetivos

- Problemas reais envolvem usualmente considerações simultâneas de critérios múltiplos de desempenho, conhecidos como Problemas Multi-Objetivos.
- Um Problema Multiobjetivo possui:
  - um conjunto de funções objetivo;
  - restrições que devem ser satisfeitas.

$$\mathbf{f}(\mathbf{x}) = [f_1(\mathbf{x}) \ f_2(\mathbf{x}) \ \dots \ f_m(\mathbf{x})]^T$$

sujeito a:


$$\begin{aligned} \mathbf{x} &\in [x_{min}, x_{max}]^n \\ g_j(\mathbf{x}) &\leq 0, j = 1, \dots, q \\ h_j(\mathbf{x}) &= 0, j = q + 1, \dots, p \end{aligned}$$





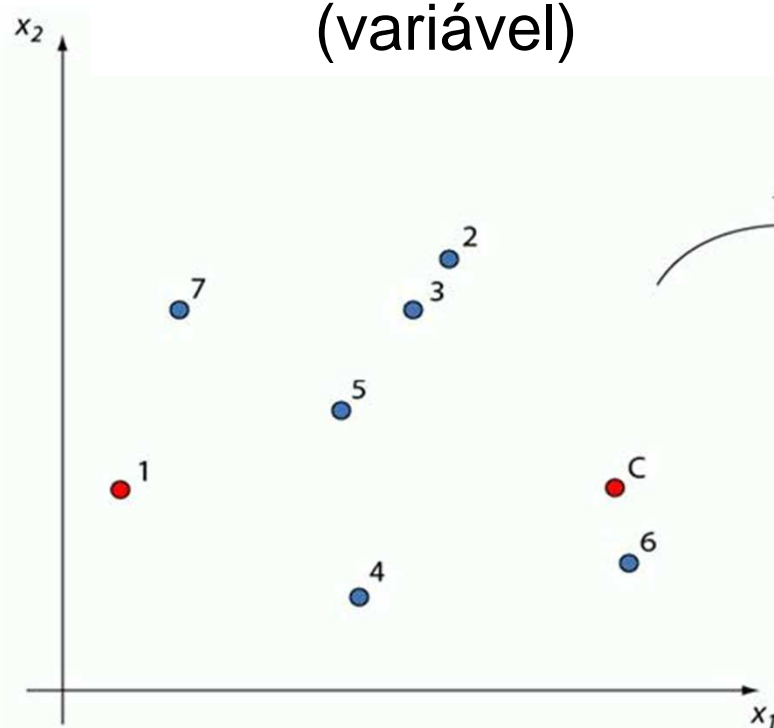
# AEs e Controle: Problemas Multi-Objetivos

- Os objetivos são frequentemente não mensuráveis, e muitos deles conflitantes entre si.
  - A melhora de um objetivo implica na piora de outro, portanto é necessário se procurar um *trade-off* para o sistema.

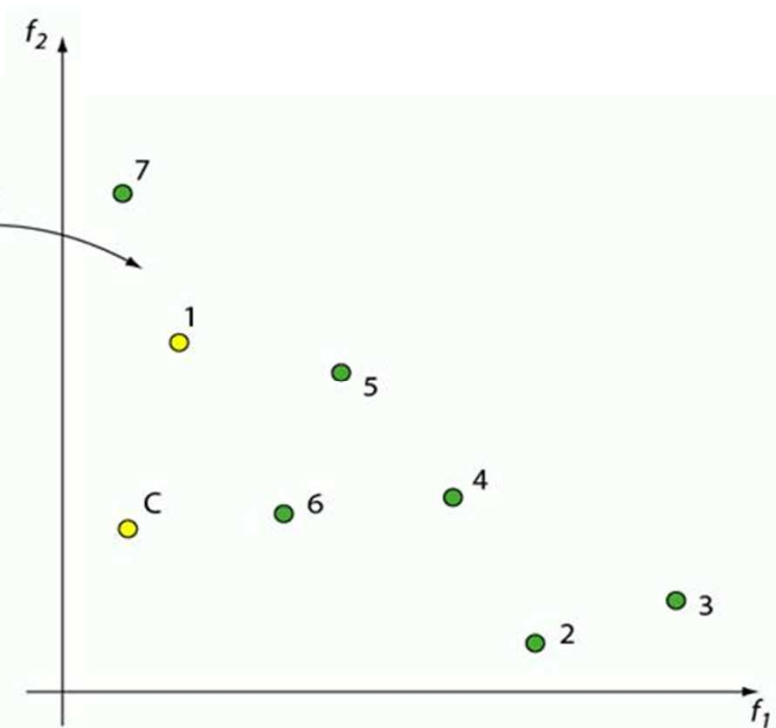


# AEs e Controle: Problemas Multi-Objetivos

Espaço de decisão  
(variável)

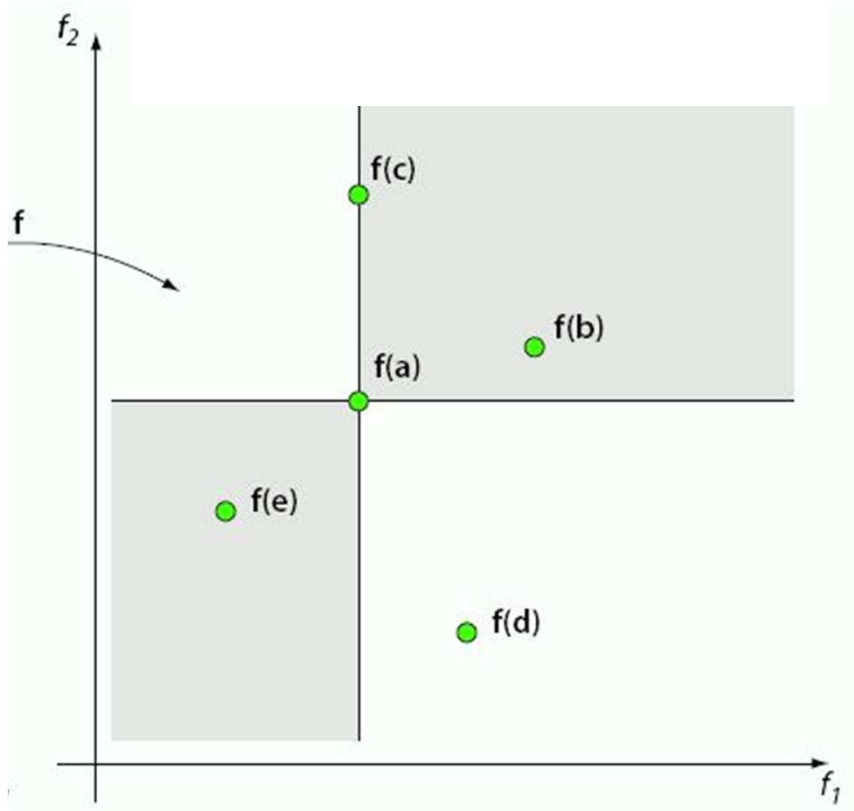


Espaço Objetivo



# AEs e Controle: Problemas Multi-Objetivos

## Espaço Objetivo



- Tarefa de otimização:  
Minimizar  $f_1$  e  $f_2$
- Comparação das soluções:  
 $a$  é melhor do que  $b$   
 $a$  é melhor do que  $c$   
 $a$  é pior do que  $e$   
 $a$  e  $d$  não podem se comparar

# AEs e Controle: Problemas Multi-Objetivos

- **Dominância de um vetor de decisão:** Uma solução  $\mathbf{x}$  domina uma outra solução  $\mathbf{y}$  (representado como  $\mathbf{x} < \mathbf{y}$ ), em um processo onde as funções objetivo devem ser minimizadas, se e somente se:
  - A solução  $\mathbf{x}$  não é pior que  $\mathbf{y}$  em todos os objetivos, isto é,  
$$f_j(\mathbf{x}) \leq f_j(\mathbf{y}), \forall j = 1, 2, \dots, m.$$
  - A solução  $\mathbf{x}$  é estritamente melhor que  $\mathbf{y}$  em pelo menos um objetivo, isto é,  
$$\exists i = 1, \dots, m : f_i(\mathbf{x}) < f_i(\mathbf{y}).$$
- **Ótimo de Pareto:** Um vetor  $\mathbf{x}^*$  é ótimo de Pareto se não existe um vetor  $\mathbf{x} \neq \mathbf{x}^* \in F$  que o domine, isto é,  $\nexists j : f_j(\mathbf{x}) < f_j(\mathbf{x}^*)$ . Se  $\mathbf{x}^*$  é ótimo de Pareto, então o vetor dos objetivos,  $\mathbf{f}(\mathbf{x}^*)$ , é também ótimo de Pareto.

# AEs e Controle: Problemas Multi-Objetivos

- **Conjunto Ótimo de Pareto ( $POS^*$ ):** É formado pelo conjunto de todos os vetores de decisão ótimos de Pareto, isto é:

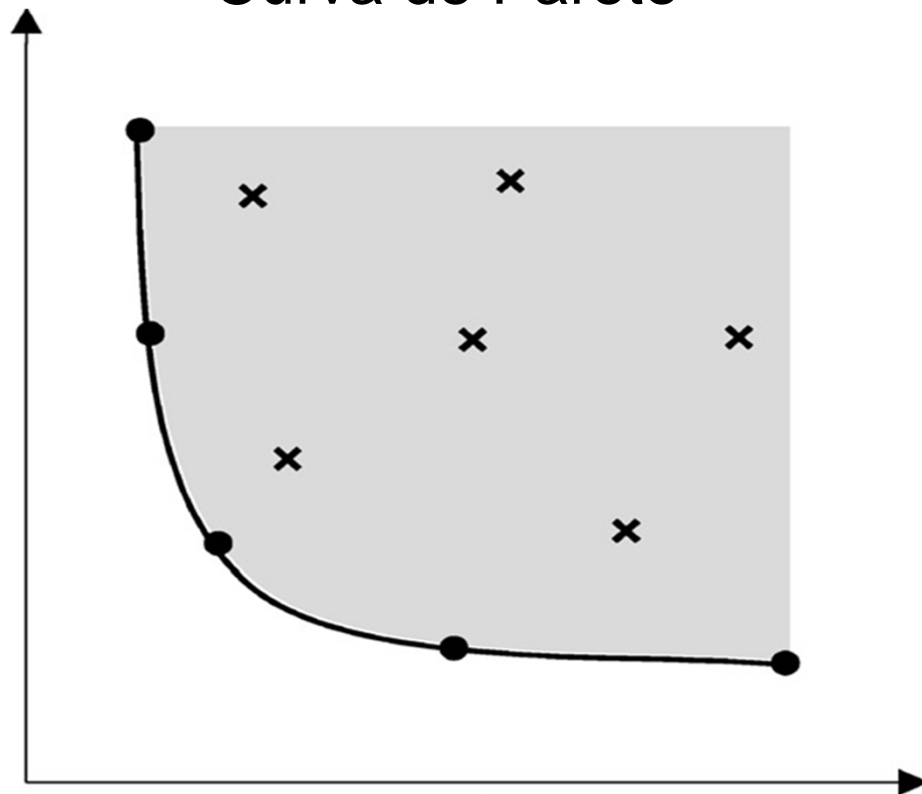
$$POS^* = \{\mathbf{x}^* \in S_{dec} \mid \nexists \mathbf{x} \in F: \mathbf{x} < \mathbf{x}^*\}$$

- **Frente Ótima de Pareto ( $POF^*$ ):** Para o vetor objetivo  $\mathbf{f}(\mathbf{x})$ , cujo conjunto ótimo de Pareto é  $POS^*$ , a frente ótima de Pareto  $POF^* \subseteq S_{obj}$  é definida como:

$$POF^*(t) = \{\mathbf{f}(\mathbf{x}^*) = [f_1(\mathbf{x}) \ f_2(\mathbf{x}) \ \dots \ f_m(\mathbf{x})]^T \mid \mathbf{x}^* \in POS^*\}$$

# AEs e Controle: Problemas Multi-Objetivos

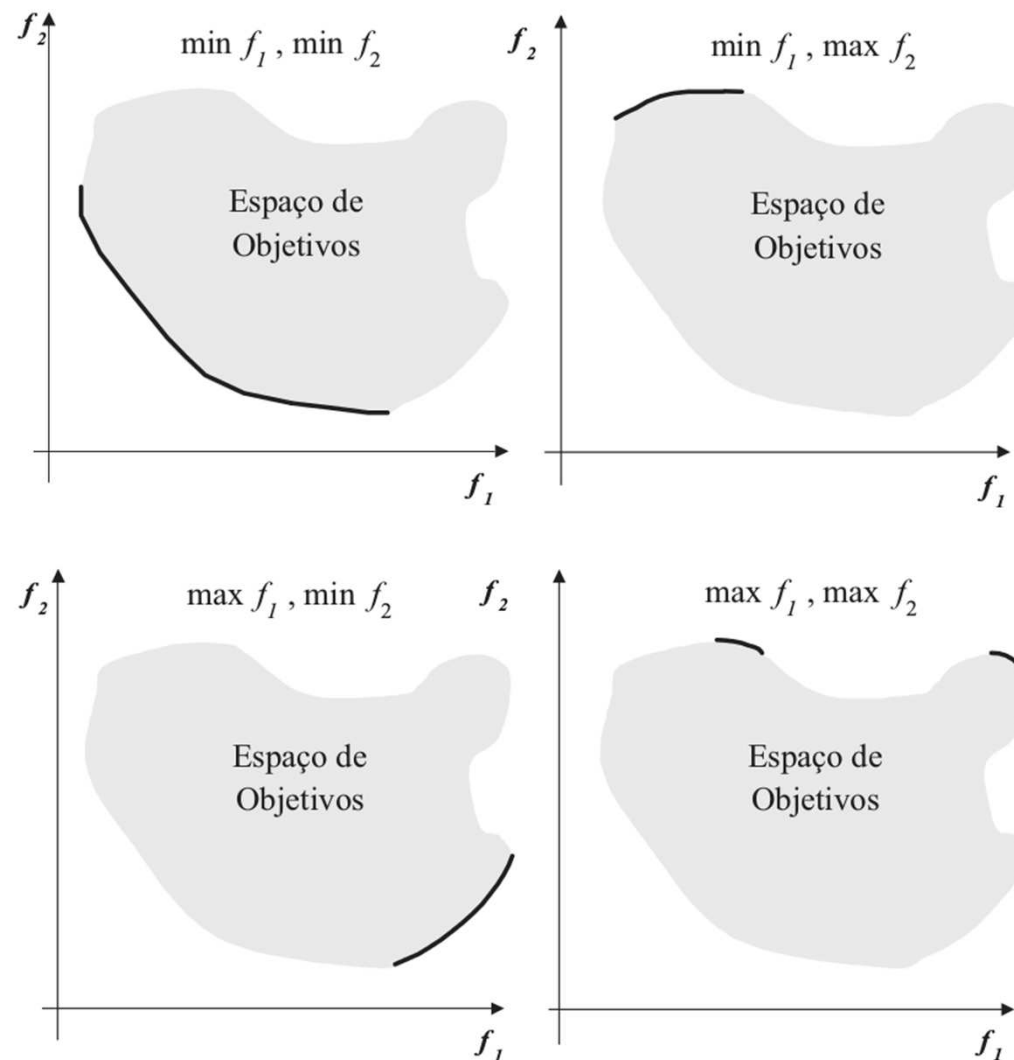
Curva de Pareto



Key:	●	nondominated solution
	×	dominated solution
	■	dominated feasible region
	—	trade-off surface

Em um problema  $n$ -dimensional a Fronteira de Pareto será uma hiper-superfície.

# AEs e Controle: Problemas Multi-Objetivos




# AEs e Controle: Problemas Multi-Objetivos


## Metas em Otimização Multi-Objetivo:

1. Encontrar um conjunto de soluções que esteja o mais próximo possível da fronteira de Pareto;
2. Encontrar um conjunto de soluções com a maior diversidade possível;
3. Realizar as duas metas anteriores com a maior eficiência computacional possível.

É desejável que as soluções estejam adequadamente distribuídas no espaço de decisões e no espaço de objetivos



Fronteira de Pareto a



Fronteira de Pareto b





# AEs e Controle: Problemas Multi-Objetivos

- Geralmente, nos problemas na engenharia de controle há uma série de objetivos de design concorrentes que são necessários para serem satisfeitos simultaneamente.
- A Frente de Pareto representa a solução ótima para o problema. Qualquer outra solução que tente melhorar um objetivo, irá piorar outro(s) objetivo(s) do sistema. A Fronteira de Pareto é a curva *trade-off*.
- Convencionalmente, os membros do conjunto de soluções ótimas de Pareto são procuradas com **métodos de programação não-linear**, os quais **não podem lidar bem** com a multimodalidade e as descontinuidades no espaço de funções e, portanto, só pode se esperar que elas produzam soluções locais.

# AEs e Controle: Problemas Multi-Objetivos

- Os EAs têm o potencial de se tornar métodos poderosos para a otimização multiobjetiva, incluindo o engenheiro de controle no processo de design como tomador de decisão.
- Os trade-offs entre os critérios de design e suas interações, e o conhecimento e a experiência dos engenheiros podem ser empregados para tomar uma decisão com base em requisitos de projeto e não nas propriedades das funções objetivas.
- Os EAs que resolvem problemas de otimização de múltiplos objetivos são chamados Algoritmos Evolucionários Multi-Objetivos (MOEAs).

# AEs e Controle: Problemas Multi-Objetivos

- Classificação dos MOEAs
  - Técnicas de primeira geração
    - Abordagens não-Pareto
    - Técnicas baseadas em Pareto
  - Técnicas de segunda geração
    - PAES, SPEA2, NSGA-II, NSGA-III, MOMGA, micro-GA, RM-MEDA, MOEA/D ...

# AEs e Controle: Problemas Multi-Objetivos

- Nas abordagens não-Pareto, geralmente, os problemas multi-objetivos eram descritos por uma única função de *custo* que ponderava a importância de cada objetivo.
  - Precisava-se de informações sobre cada objetivo do problema para efetuar a ponderação da função de custo;
  - Estas informações, em geral, não estavam disponíveis;
  - Era necessário efetuar vários testes para buscar uma configuração de pesos adequados;
  - Abordagens com ponderação de pesos eram incapazes de detectar a parte não convexa na superfície de *trade-off*.

# AEs e Controle: Problemas Multi-Objetivos

- As técnicas baseadas em Pareto reúnem MOEAs (1989 - 1998), que se caracterizam pela simplicidade dos algoritmos e pela ausência de métricas para comparação dos mesmos. A avaliação dos algoritmos era feita de forma visual.
- Uso de classificação e seleção baseada em não-dominância para mover a população para a frente de Pareto
- Requerem um procedimento de classificação e uma técnica para manter a diversidade na população.
- Exemplo: MOGA (1993) proposto por Fonseca and Fleming, o qual era eficiente e fácil de implementar. Seu desempenho depende da seleção apropriada do fator de compartilhamento. MOGA foi o MOEA de primeira geração mais popular.

# AEs e Controle: Problemas Multi-Objetivos

- As técnicas de segunda geração introduziram o conceito de elitismo e utilizaram uma população externa (exceto o NSGA-II) para manter as melhores soluções encontradas durante o processamento do algoritmo.
- As questões de design incluem
  - Como o arquivo externo interage com a população principal?
  - O que fazemos quando o arquivo externo está cheio?
  - Colocamos critérios adicionais para entrar uma solução no arquivo em vez de usar apenas dominância de Pareto????
- Nesta fase, os MOEAs introduziram técnicas como, por exemplo, grid adaptativo e entropia para promover a diversidade das soluções.

# AEs e Controle: Problemas Multi-Objetivos

Primeiras aplicações em Controle:

- Liu & Patton (1994) apresentam o desenvolvimento de algoritmos de otimização multiobjetivo para controle robusto multivariável por AGs.
- Os aspectos relativos a otimização multiobjetivo e esquemas baseados na definição de otimalidade de Pareto têm sido alvo de pesquisas por Chipperfield & Fleming (1996) e Fonseca & Fleming (1995).
- Takahashi et al. (1997) apresentam uma metodologia de otimização multiobjetivo em projeto de compensadores PID para sistemas sujeitos a perturbações e incertezas paramétricas. Este estudo apresenta uma comparação de desempenho e complexidade computacional dos AGs em relação a algoritmos baseados em gradiente.

# AEs e Controle: Tratamento de Restrições

- Todos os problemas de engenharia de controle possuem restrições, seja sobre a estabilidade do sistema, limites do atuador, planta, entre outras.
- As restrições podem ser tratadas:
  - Na codificação do cromossomo
    - Restringindo soluções inviáveis.
  - Em funções de penalidade
    - Caso as restrições não possam ser codificadas geneticamente. Estas funções atribuem um custo muito alto (ou, conseqüentemente, uma condição física muito baixa) a soluções inviáveis.



# AEs e Controle: Tratamento de Restrições

- As restrições podem ser tratadas:
  - Com algoritmos de reparo
    - Procurando na vizinhança de uma solução inviável, soluções viáveis. A adequação dessas novas soluções geralmente é reduzida em uma quantidade equivalente ao "custo" do reparo associado.
  - Como uma otimização multi-objetivo
    - Transformando as restrições em objetivos e passando a enxergar o problema como multi-objetivo. Esta técnica pode se tornar mais popular à medida que a pesquisa MOEA se expande.

# AEs e Controle: Controle Robusto

- Controladores projetados utilizando controle robusto estão aptos a superarem pequenas diferenças (incertezas) entre o modelo real da planta e o modelo nominal utilizado para o projeto.
- O controlador é projetado para funcionar assumindo que certas variáveis serão desconhecidas, mas limitadas.

# AEs e Controle: Controle Robusto

- Uma abordagem para o projeto de sistemas de controle robustos é através da atribuição de estrutura. Patton e Liu (1994) mostraram uma abordagem híbrida combinando GAs e otimização baseada em gradiente. Seu esquema foi aplicado ao projeto de um sistema de controle lateral de aeronave.
- Em outra abordagem, Dakev et al. (1995) empregam um EA para encontrar funções de ponderação adequadas para um controlador MIMO robusto para um sistema crítico. O problema de design considerado era um sistema de suspensão EMS para um veículo levitável magneticamente.

# AEs e Controle: Integração do Sistema

- Além do problema de projetar controladores para fornecer um desempenho ótimo, os controladores devem, no entanto, ser integrados em todo o sistema.
- O objetivo da integração de sistemas é, considerar a integração do sistema de controle com os requisitos de planta e interface com outros sistemas de interação, e a estrutura, para levar a melhorias na segurança, eficiência, peso, confiabilidade e custos operacionais.
- O problema de integração de sistemas é comum a muitas aplicações industriais e pode ser colocado dentro de uma estrutura multiobjetiva. No entanto, geralmente foi encontrado que possui propriedades que o tornam impróprio para técnicas de otimização convencionais.

# AEs e Controle: Integração do Sistema

- A variável de decisão é uma mistura de parâmetros discretos e contínuos e os objetivos de projeto abrangem uma ampla gama de medidas, desde o desempenho do controlador até considerações mecânicas.
- As funções objetivas podem, em geral, ser esperadas para serem altamente não-lineares e exibir um alto grau de interação entre si.
- O uso de métodos evolutivos tem potencial para pesquisar superfícies de função objetivas complexas, incorporando o conhecimento dos designers tanto na formulação quanto na solução do problema (ver, por exemplo, Parmee e Denham (1994)).

# Exemplo de Aplicação

**Controlador PID para Controle de Processo sintonizado com Algoritmo Genético Multi-Objetivo (MOGA).** Mohit Jain, Vijander Singh & Asha Rani (2013)

$$G_1(s) = \frac{e^{-0,5s}}{(s + 1)^2}$$

$$G_2(s) = \frac{4,288}{(s + 0,5)(s^2 + 1,64s + 8,456)}$$

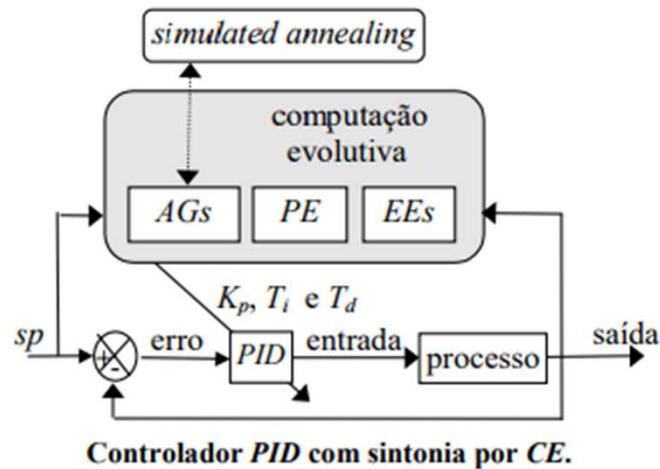
$$G_3(s) = \frac{27}{(s + 1)(s + 3)^3}$$

- $G_1(s)$  é um sistema de segunda ordem com atraso,
- $G_2(s)$  é um sistema de terceira ordem,
- $G_3(s)$  é um sistema de quarta ordem.

Os três processos mostram um comportamento dinâmico muito complexo.

# Exemplo de Aplicação

Configuração para o projeto e controle PID



Equação padrão do controle PID digital

$$u(k) = u(k - 1) + q_0 e(k) + q_1 e(k - 1) + q_2 e(k - 2)$$

onde as constantes  $q_0$ ,  $q_1$  e  $q_2$  satisfazem:

$$q_0 = K_p \left( 1 + \frac{T_s}{2T_i} + \frac{T_d}{T_s} \right)$$

$$q_1 = -K_p \left( 1 + \frac{2T_d}{T_s} - \frac{T_s}{2T_i} \right)$$

$$q_2 = K_p \frac{T_d}{T_s}$$

- $K_p$  é a constante de ganho proporcional,
- $T_i$  é a constante de tempo integral,
- $T_d$  é a constante de tempo derivativo.
- $T_s$  é período de amostragem.

# Exemplo de Aplicação

Funções de fitness multi-objetivos consideradas:

$$f_1 = 0,05ISE$$

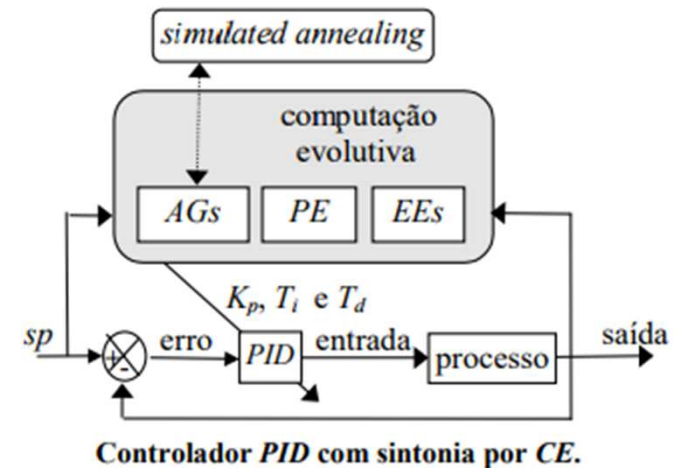
$$f_2 = 0,05t_s$$

$$f_3 = 0,90OS$$

onde

- $t_s$  é o tempo de assentamento dentro de 5 por cento,
- $OS$  é a porcentagem de sobre-elevação,
- $ISE$  é Integral do erro ao quadrado:

$$ISE = \int_0^T e^2(t)dt$$

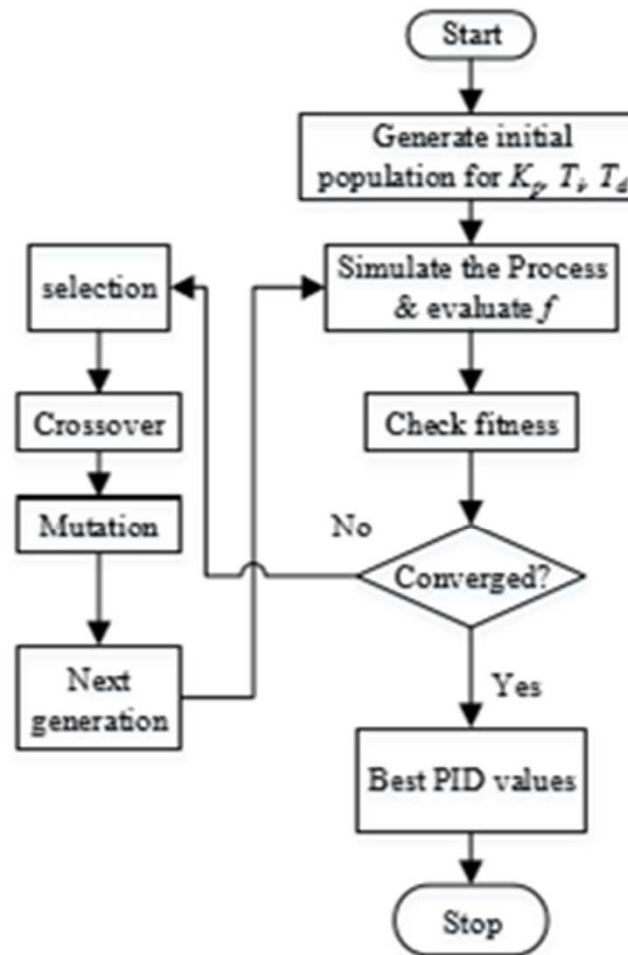




# Exemplo de Aplicação

- O peso máximo é atribuído ao OS, o que significa que minimizar a sobre-elevação é o principal requisito do sistema em consideração.
- No lugar do ISE, pode-se usar a Integral do erro absoluto ponderado no tempo (ITAE) ou a Integral do valor absoluto do erro (IAE).
- O engenheiro de controle escolhe qual parâmetro particular do sistema de controle precisa de mais atenção atribuindo um peso maior enquanto se consideram outras especificações simultaneamente.
- A soma total dos pesos deve ser igual a um, de modo que o desempenho geral do sistema deve ser justificado.
- Os EAs mostram a flexibilidade na sintonia do PID.

# Exemplo de Aplicação



# Exemplo de Aplicação

Parâmetros do MOGA;

TABLE I. GENETIC ALGORITHM OPERATORS AND PARAMETERS

Parameter	Value/Method
Population Type	Double vector
Population Size	20
Creation function	Feasible population
Selection method	Tournament
Mutation	Adaptive feasible
Crossover	Arithmetic
Generations	65

# Exemplo de Aplicação




Fig. 2 : Step response of process  $G_1(s)$




Fig. 3 : Step response of process  $G_2(s)$

Estudo comparativo com outros métodos clássicos:

- Z-N: Ziegler-Nichols
- Kitamori: controlador PID de Kitamori
- T-L: controlador de Tyreus e Luyben




Fig. 4 : Step response of process  $G_3(s)$

# Exemplo de Aplicação

TABLE II. SUMMARY OF COMPARATIVE STUDY

Process	Index	Z-N	Kitamori	T-L	MOGA
G1	$K_p$	2.808	2.212	2.1328	2.1245
	$T_i$	1.64	2.039	7.194	2.3329
	$T_d$	0.41	0.519	0.519	0.5556
	%OS	32	6.8	0	0
	$t_s$ ( $\pm 5\%$ )	4.16	2.37	16.03	1.57
G2	$K_p$	2.19	-	1.659	2.3505
	$T_i$	1.03	-	4.532	2.6756
	$T_d$	0.258	-	0.3269	0.4470
	%OS	17	-	0	0
	$t_s$ ( $\pm 5\%$ )	5.45	-	12.02	4.22
G3	$K_p$	3.072	2.357	2.3272	1.9827
	$T_i$	1.352	1.649	5.9488	1.8419
	$T_d$	0.338	0.414	0.4292	0.4533
	%OS	32.8	10.9	0	$8.8 \times 10^{-14}$
	$t_s$ ( $\pm 5\%$ )	3.722	2.3	13.09	1.52

The sign '-' indicates that these values are not provided in the literature

Estudo comparativo com outros métodos clássicos:

- Z-N: Ziegler-Nichols
- Kitamori: controlador PID de Kitamori
- T-L: controlador de Tyreus e Luyben

# Bibliografia Básica

- Coello, C. A. C. (2000). Handling Preferences in Evolutionary Multiobjective Optimization: A Survey. *Proceedings of the 2000 congress on evolutionary computation*, Vol. 1. San Diego, USA (pp. 30–37).
- Deb, K. (1999). Evolutionary algorithms for multi-criterion optimization in engineering design. In: K. Miettinen et al. (Eds.), *Evolutionary algorithms in engineering and computer science* (pp.135–161). Chichester: Wiley.
- Fleming, P. J., & Purhouse, R. C. (2002). *Control Engineering Practice*, 10, pp. 1223–1241.

# Bibliografia Básica

- Fonseca, C.M., & Fleming, P. J. (1993). Genetic algorithms for multiobjective optimisation: Formulation, discussion and generalization, *Proceedings of the fifth international conference on genetic algorithms*. San Mateo, USA (pp. 416–423).
- Fonseca, C. M., & Fleming, P. J. (1995). An overview of evolutionary algorithms in multiobjective optimization. *Evolutionary Computation*, 3(1), 1–16.
- Veldhuizen, D. A. V., & Lamont, G. B. (2000). Multiobjective evolutionary algorithms: Analyzing the state-of-the-art. *Evolutionary Computation*, 8(2), 125–147.

# Bibliografia Básica

- Coelho, Leandro S., & Coelho, Antônio AR. Algoritmos evolutivos em identificação e controle de processos: uma visão integrada e perspectivas. *SBA Controle & Automação*, 1999, 10.01: 13-30.
- Chipperfield, Andrew, & Fleming, Peter. An overview of evolutionary algorithms for control systems engineering. *Evolutionary Computation Research*, 2002
- Vaidyanathan, Sundarapandian, & Volos, Christos. *Advances and applications in nonlinear control systems*. Springer, 2016.



# Bibliografia Básica

- Mohit, J., Vijander, S., & Asha, R. Performance Analysis of Multi-objective Genetic Algorithm Tuned PID Controller for Process Control. *International Journal on Advanced Computer Theory and Engineering (IJACTE)*, 2, 2319-2526.
- Reynoso-Meza, G., Sanchis, J., Blasco, X., & Freire, R. Z. (2016). Evolutionary multi-objective optimisation with preferences for multivariable PI controller tuning. *Expert Systems with Applications*, 51, 120-133.